



DOI:10.12404/j.issn.1671-1815.2309596

引用格式:杨青华,杨观赐,钟世昊.基于正交优化策略的YOLO模型超参数优化方法[J].科学技术与工程,2025,25(4):1573-1579.

Yang Qinghua, Yang Guanci, Zhong Shihao. Hyperparameter optimization of YOLO model based on orthogonal optimization strategy[J]. Science Technology and Engineering, 2025, 25(4): 1573-1579.

基于正交优化策略的YOLO模型超参数优化方法

杨青华,杨观赐*,钟世昊

(贵州大学现代制造技术教育部重点实验室,贵阳550025)

摘要 为实现YOLO(you only look once)模型的超参数自动优化,提出基于正交优化策略的YOLO模型超参数优化方法(hyper-parameter optimization of YOLO model based on orthogonal optimization strategy, OOS)。首先基于统计学的正交试验原理,提出了种群的正交搜索方法与超参数贡献度分析策略,提高了算法的优化效率;然后,设计了均匀正交搜索策略和邻域正交搜索策略,以缓解YOLO模型陷入局部最优和早熟收敛问题。最后,在NWPU VHR-10和Pascal VOC两个目标检测数据集上,以YOLOv5、YOLOv5s-Transformer和YOLOv7为优化对象进行测试,测试结果表明,所提出的OOS超参数优化方法对于YOLO模型的识别精度均有所提升。在两个数据集上的平均识别精度mAP@0.5分别提升至93.94%、93.18%、93.45%以及85.81%、84.59%、90.62%;mAP@0.5-0.95提升至60.00%、60.08%、56.98%以及62.27%、58.89%、71.91%,可为目标检测模型的超参数智能优化提供一种新方法。

关键词 目标检测;超参数优化;正则化策略;YOLO

中图分类号 TP391.41; **文献标志码** A

Hyperparameter Optimization of YOLO Model Based on Orthogonal Optimization Strategy

YANG Qing-hua, YANG Guan-ci*, ZHONG Shi-hao

(Key Laboratory of Advanced Manufacturing Technology of Ministry of Education, Guizhou University, Guiyang 550025, China)

[Abstract] In order to realize the automatic optimization of hyperparameters of YOLO model, the hyperparameter optimization of you only look once (YOLO) model based on orthogonal optimization strategy (OOS) was proposed. Firstly, based on the principle of statistical orthogonal test, the orthogonal search method of population and the hyperparameter contribution analysis strategy were proposed to improve the optimization efficiency of the algorithm. Then, the uniform orthogonal search strategy and the neighborhood orthogonal search strategy were designed to alleviate the problem of the YOLO model falling into the local optimum and premature convergence. Finally, YOLOv5, YOLOv5s-Transformer and YOLOv7 were used as optimization objects to test on two target detection datasets, NWPU VHR-10 and Pascal VOC. Test results show that the recognition accuracy of the YOLO model is improved by the OOS hyperparameter optimization method in all cases. The average recognition accuracy mAP@0.5 on two datasets is improved to 93.94%, 93.18%, 93.45%, and 85.81%, 84.59%, 89.96%. The mAP@0.5-0.95 is improved to 60.00%, 60.08%, 56.98%, and 62.27%, 58.89%, 70.77%. It can provide a new intelligent method for hyperparameter optimization of object detection model.

[Keywords] object detection; hyperparameter optimization; regularization strategy; YOLO

当前,机器视觉技术已成为现代工业的核心技术之一,机器视觉系统被广泛应用于半导体、机器人与工厂自动化、汽车制造等行业。在实际应用中,目标检测任务是机器视觉领域的核心任务之一,而选择合适的超参数是提升目标检测模型性能的关键。当前,目标检测模型YOLO(you only look once)虽然在检测实时性和精度方面表现出色,且已被广

泛应用在多目标跟踪^[1-2]、自动驾驶^[3]、机器人^[4]、医学图像分析^[5]、施工检测^[6-7]、菜品识别^[8]等,但如何通过优化模型超参数平衡实时性与检测精度,在确保检测实时性的基础上提高模型检测精度依然是研究热点^[9]。当前,网格搜索(grid search, GS)、随机搜索(random search, RS)和遗传算法(genetic algorithm, GA)被广泛用于超参数优化。

收稿日期:2023-12-05; 修订日期:2024-11-08

基金项目:国家自然科学基金(62163007,62373116);贵州省科技计划(黔科合平台人才[2020]6007-2,黔科合支撑[2021]一般439)

第一作者:杨青华(1999—),男,汉族,重庆云阳人,硕士研究生。研究方向:深度学习。E-mail:qinghy_gzu@163.com。

*通信作者:杨观赐(1983—),男,汉族,湖南嘉禾人,博士,教授。研究方向:自主智能系统与机器人、多模态数据融合认知计算。E-mail:gcyang@gzu.edu.cn。

投稿网址:www.stae.com.cn

基于网格搜索的超参数优化方面, Kaur 等^[10]利用 GS 为神经网络寻找最佳超参数, 在帕金森患者分类任务中, 模型的平均分类准确率达到了 91.69%。López 等^[11]提出了基于规则的改进 GS, 优化支持向量机的超参数, 在波士顿数据集上取得了更好排名。文献[12]提出了基于多层长短期记忆(long short-term memory, LSTM)网络的需求预测方法, 将 GS 用于优化 LSTM 超参数的不同组合, 测试结果表明优于循环神经网络、支持向量机和单层 LSTM 等方法。虽然这类方法在寻找模型超参数方面取得了不错的效果, 但随着参数量的增加计算量呈指数级增长。

基于随机搜索的超参数优化方面, Motta 等^[13]采用 RS 优化卷积神经网络(convolutional neural network, CNN)的超参数, 在包含 8 700 张图像的数据集上对导致特定疾病的蚊子进行分类, 图像识别的准确率从 76% 提高到 93%。为解决用水量预测问题, Gil-Gamboa 等^[14]使用 RS 优化深度前馈神经网络的隐藏层层数和神经元个数, 使模型的错误率从 7.02% 下降到 5.59%。文献[15]提出了基于 RS 的深度随机配置网络层数、节点数、激活函数优化方法, 在 4 个机器学习数据集的测试结果表明, 基于该方法获得了具有更优性能的深度随机配置网络。此类方法虽然难以获得理论最优参数, 但其计算复杂度低于基于 GS 的超参数优化方法。

基于遗传算法的超参数优化方面, 有学者将 GA 运用到神经网络的架构优化^[16], 在 CIFAR-10 分类数据集的测试结果表明, 基于 GA 的超参数优化方法优于基于 GS 和 RS 的方法, 具有更高的建模准确性和更短的计算时间。针对城市景观服务质量预测任务, 有研究运用 GA 优化神经网络的神经元个数、层数、初始权值^[17], 使预测准确率由 70% 提高到 90%。为解决机械结构位移和应力分布预测问题, 文献[18]究运用 GA 对神经网络的神经元层数和个数进行优化, 使预测误差相比原模型降低 38%。此类方法通过所设置的适应度函数引导搜索趋近最优, 虽然具有良好的搜索效率, 但是容易陷入局部最优和早熟收敛。

鉴于此, 为了优化 YOLO 模型超参数, 基于统计学正交试验原理, 在设计种群的正交搜索方法、超参数贡献度分析策略及均匀正交搜索策略和邻域正交搜索策略的基础上, 提出基于正交优化策略的 YOLO 模型超参数优化方法(hyperparameter optimization of YOLO model based on orthogonal optimization strategy, OOS), 为目标检测模型的超参数智能优化提供新途径。

1 基于正交优化策略的 YOLO 模型超参数优化方法

1.1 算法主体流程

正交试验设计是基于正交设计理论, 研究多因素多水平的试验设计方法, 它利用正交阵列(又称为正交表)选择具有均匀分散性和整齐可比性的代表性子集。通常, 正交阵列采用正交拉丁方法构建^[19]。正交性作为正交表的基本特性, 主要特点如下。

(1) 均匀分散性。即任意一列因素中, 所有水平值出现的次数相等。它能够确保在每个水平内最大限度地排除其他因素水平的干扰, 因此使部分实验的最优解与全面实验的最优解具有一致的趋势。

(2) 整齐可比性。即任意两列之间各种不同水平的所有可能组合出现的次数相等。它能够确保试验点在因素和水平的完全组合中均匀分布, 从而使部分实验具有代表性和综合可比性。

因此, 为实现 YOLO 模型的超参数自动优化, 本节提出基于正交优化策略的 YOLO 模型超参数优化方法, 伪代码如算法 1 所示。

算法 1: 基于正交优化策略的 YOLO 模型超参数优化方法。

```

输入: 图像和标签 | Image, Label |
输出: 最佳的超参数、模型适应度  $g_{best}$ 
步骤 1: 初始化: 步长因子  $c$ , 阶段数  $T$ , 最大进化代数  $N$ , 边界约束矩阵  $I_{limit}$ , 用 1.4 节中的式(11)初始化正则化策略的状态矩阵  $S_{s \times m}$  (其中,  $s$  为超参数的状态数,  $m$  为超参数的个数), 采用 1.2 节的种群的正交搜索方法得到初始化的正交搜索种群  $X_{n \times m}$  (其中  $n$  为种群数), 初始化全体  $x_j$  的适应度  $f_j$  形成矩阵  $F_{1 \times n}$ 
步骤 2: For ( $i = 1$  to  $N - 1$ ) do
步骤 3: For ( $j = 0$  to  $n - 1$ ) do
步骤 4: 训练并验证模型 Model( $x_j$ , Image), 得到  $x_j$  的适应度  $f_j$ 。
步骤 5: End for
步骤 6: 找到当前种群的最优个体  $g_{best}X$  及其适应度  $g_{best}$ 
步骤 7: 按照 1.3 节中的式(6) ~ 式(8)计算得到新个体  $s_{best}X$ 
步骤 8: 训练并验证模型 Model( $s_{best}X$ , Image) 得到适应度  $s_{best}$ 
步骤 9: 将  $s_{best}$  和  $g_{best}$  做比较, 保留最优适应度更新  $g_{best}$ , 保留相应的最优个体更新  $g_{best}X$ 
步骤 10: 更新正交搜索种群  $X_{n \times m}$ 
步骤 10.1: If ( $i + 1 \leq T$ ) then
步骤 10.2: 按照 1.4 节中的式(11)更新状态矩阵  $S_{s \times m}$ 
步骤 10.3: Else
步骤 10.4: 按照 1.4 节中的式(12)更新状态矩阵  $S_{s \times m}$ 
步骤 10.5: 通过 1.2 节中种群的正交搜索方法得到更新后的正交搜索种群  $X_{n \times m}$ 
步骤 11: End for
步骤 12: 返回当前的最优个体对应的最佳策略超参数  $g_{best}X$ , 最优模型适应度  $g_{best}$ 
    
```

对任意一张图像 $\text{Image} \in \mathbf{R}^{3-H-W}$, 对应标签 $\text{Label} \in \mathbf{R}^{t-\text{class}-x-y-w-h}$, 其中, H, W 分别为输入图像的高和宽, t 为一个图像中的目标数, class 为目标类别, $(x, y), w, h$ 分别为目标框的中心点坐标、宽、高。

步骤1中,超参数包括13种:OneCycle学习率衰减策略的两个参数 l_{0} 和 l_{r} , 以及数据增强策略 HSV-Saturation、HSV-Value、degrees、translate、scale、perspective、flipud、fliplr、mosaic^[20]、mixup^[21]、copy-paste^[22] 的11个参数。适应度计算公式见式(9)。

1.2 种群的正交搜索方法

为更好地对搜索过程进行剪枝、提升优化效率,基于统计学的正交试验原理提出种群的正交搜索方法。种群的正交搜索方法由正交阵列、状态矩阵和正交映射策略组成。正交阵列规定种群中各个体状态组合结构,状态矩阵对应每个超参数在单次迭代中的多个状态值。通过正交映射策略,将状态矩阵映射到正交搜索种群中。

1.2.1 定义

设种群个体为 $x_i = \{x_{i0}, x_{i1}, x_{i2}, \dots, x_{ij}, \dots, x_{im}\}$, 则搜索种群如式(1)所示。

$$\mathbf{X}_{n \times m} = \begin{bmatrix} x_{00} & x_{01} & \cdots & x_{0m} \\ x_{10} & x_{11} & \cdots & x_{1m} \\ \vdots & \vdots & & \vdots \\ x_{n0} & x_{n1} & \cdots & x_{nm} \end{bmatrix} \quad (1)$$

将正向传播视为一个复合函数 F , 则搜索种群对应的适应度向量 \mathbf{Y} 按式(2)计算。

$$\mathbf{Y} = \mathbf{F}(\mathbf{X}_{n \times m}) = \begin{bmatrix} f([x_{00} & x_{01} & \cdots & x_{0m}]) \\ f([x_{10} & x_{11} & \cdots & x_{1m}]) \\ \vdots \\ f([x_{n0} & x_{n1} & \cdots & x_{nm}]) \end{bmatrix} = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_n \end{bmatrix} \quad (2)$$

在一个搜索种群中,若个体含 m 个超参数,每个超参数均有 s 个状态值(s 默认取3),便构成式(3)所示的状态矩阵 $\mathbf{S}_{s \times m}$ 。

$$\mathbf{S}_{s \times m} = \begin{bmatrix} x_{00} & x_{01} & \cdots & x_{0m} \\ x_{10} & x_{11} & \cdots & x_{1m} \\ \vdots & \vdots & & \vdots \\ x_{s0} & x_{s1} & \cdots & x_{sm} \end{bmatrix} \quad (3)$$

1.2.2 正交映射策略

(1)个体的超参数维度 m 匹配到唯一的正交表。根据正交表获得数组 $\mathbf{MS} = \{m_{s1}, m_{s2}, \dots, m_{sk}\}$, 其中 m_{sk} 为一组正交表 $L_N(s^{m_s})$ 的列数,取 $s=3$, 因此, m 个超参数可以匹配到唯一正交表 $L_N(3^{m_s})$, 正交表与 m 的对应关系为

$$m_s = \min(\{m_s \geq m \mid m_s \in \mathbf{MS}\})$$

(2)根据式(4)状态矩阵 $\mathbf{S}_{s \times m}$ 到正交阵列 $\mathbf{L}_{n \times m}$ 的映射关系,更新搜索种群 $\mathbf{X}_{n \times m}$ 。

$$\{x_{ij} = \mathbf{S}_{L_{ij}-1, j}\} \quad (4)$$

式(4)中: x_{ij} 为 $\mathbf{X}_{n \times m}$ 中第 i 个搜索向量的第 j 个超参数的值; L_{ij} 为第 i 个个体的第 j 个超参数值在 $\mathbf{L}_{n \times m}$ 中的状态序号; $\mathbf{S}_{L_{ij}-1, j}$ 为状态矩阵 $\mathbf{S}_{s \times m}$ 中第 $L_{ij}-1$ 行、第 j 列的超参数状态值。

1.3 超参数贡献度分析策略

为进一步提高算法的优化效率,利用种群的正交性特点设计超参数贡献度分析策略。

通过式(5)计算第 j 个超参数的第 l 个状态值的累计统计量 $\mathbf{K}_{l, j}$, 并将其更新至统计量矩阵 $\mathbf{K}_{s \times m}$ 。

$$\mathbf{K}_{l, j} = \sum_{i=1}^n y_i I_{\{L_{i, j}-1=l\}}, \quad l = 0, 1, \dots, s-1; j = 0, 1, \dots, m-1 \quad (5)$$

式(5)中: y_i 为适应度向量 \mathbf{Y} 中的第 i 个元素; $I_{\{L_{i, j}-1=l\}}$ 为指示函数,当 $L_{i, j}-1=l$ 时取1,否则取0。

依据式(6)~式(8)计算每一个超参数最大平均贡献的状态值索引 $s_{\text{best}, j}$ 、统计最优状态值 $x_{\text{best}, j}$ 、统计最优个体 $\mathbf{X}_{\text{ibest}}$ 。

$$s_{\text{best}, j} = \arg \max_l (\mathbf{K}_{l, j}), \quad j = 0, 1, \dots, m-1 \quad (6)$$

$$x_{\text{best}, j} = \mathbf{S}_{s_{\text{best}, j}, j}, \quad j = 0, 1, \dots, m-1 \quad (7)$$

式(7)中: $\mathbf{S}_{s_{\text{best}, j}, j}$ 为状态矩阵 $\mathbf{S}_{s \times m}$ 中第 $s_{\text{best}, j}$ 行、第 j 列的超参数状态值。

$$\mathbf{X}_{\text{ibest}} = (x_{\text{ibest}, 0}, x_{\text{ibest}, 1}, \dots, x_{\text{ibest}, j}, \dots, x_{\text{ibest}, m}) \quad (8)$$

1.4 均匀正交搜索策略和邻域正交搜索策略

为避免陷入局部最优和早熟收敛,采用两阶段更新策略,即在第一阶段采用较大步长进行均匀正交搜索,在第二阶段采用较小步长进行邻域正交搜索。

评价指标作为两阶段更新策略的重要依据,适应度 f 可以通过式(9)进行如下所示的加权计算。

$$f = 0.1 \text{mAP}@0.5 + 0.9 \text{mAP}@0.5-0.95 \quad (9)$$

式(9)中: $\text{mAP}@0.5$ 为 IOU 阈值为 0.5 的平均精度; $\text{mAP}@0.5-0.95$ 为 IOU 阈值为 0.5~0.95 的平均精度。

由输入的边界约束矩阵 $\mathbf{I}_{\text{limit}}$ 得到各超参数上界 u_j 和下界 l_j 。

$$\begin{cases} l_j = \mathbf{I}_{\text{limit}}[0, j] \\ u_j = \mathbf{I}_{\text{limit}}[1, j] \end{cases} \quad (10)$$

1.4.1 均匀正交搜索策略

搜索前期,即进化代数 $i \leq T$ 时,采取较大步长

的均匀搜索策略,以避免较快陷入局部最优。

$$\begin{cases} l_{ej} = u_j - l_j \\ S_{0,j} = \mathbf{g}_{\text{best}} \mathbf{X}_j \\ S_{1,j} = l_j + \frac{2i}{2T-1} l_{ej} \\ S_{2,j} = l_j + \frac{2i+1}{2T-1} l_{ej} \end{cases} \quad (11)$$

式(11)中: $\mathbf{g}_{\text{best}} \mathbf{X}_j$ 为全局最优个体的第 j 个参数; l_j 为第 j 个参数的定义区间长度; $S_{0,j}$ 、 $S_{1,j}$ 、 $S_{2,j}$ 分别为状态矩阵 $\mathbf{S}_{s \times m}$ 的第0、1、2行第 j 个参数的自适应更新; i 为进化代数; T 为阶段数。

1.4.2 邻域正交搜索策略

在搜索后期,即进化代数 $i > T$ 时,采取较小的自适应步长进行邻域正交搜索,以提升搜索的精细度。

在上一次搜索结束后,将得到一个搜索阵列中全局最优的个体,将该个体作为下一代的父代。

$$\begin{cases} S_{0,j} = \mathbf{g}_{\text{best}} \mathbf{X}_j \\ S_{1,j} = \mathbf{g}_{\text{best}} \mathbf{X}_{0,j} (1 - cr) \\ S_{2,j} = \mathbf{g}_{\text{best}} \mathbf{X}_{0,j} (1 + cr) \end{cases} \quad (12)$$

式(12)中: $S_{0,j}$ 为第 j 个超参数的初始状态或上一轮中保存下来的最优父代,每一个超参数都将进行参与变异,其变异状态的变异式见式(13)、式(14); $\mathbf{g}_{\text{best}} \mathbf{X}$ 为全局最优个体, $\mathbf{g}_{\text{best}} \mathbf{X}_j$ 为全局最优个体的第 j 个参数; r 为一个 $[0,1]$ 的随机数; c 为控制随机数幅度和步长的步长因子。

若父代处于边界,更新后状态值将超出定义域,因此对这种边界情况进行随机重生成。

若父代处于上界,即 $S_{0,j} = u_j$ 时,有

$$S_{2,j} = (1 - r_{\text{atio}})^2 \mathbf{g}_{\text{best}} \mathbf{X}_j \quad (13)$$

若父代处于下界,即 $S_{0,j} = l_j$ 时,

$$\begin{cases} l_{ej} = u_j - l_j \\ S_{1,j} = l_j + 0.1 r_{\text{atio}} l_{ej} \\ S_{2,j} = l_j + 0.2 r_{\text{atio}} l_{ej} \end{cases} \quad (14)$$

2 测试与分析

2.1 实验设置

(1)数据集。实验使用NWPU VHR-10遥感数据集,PASCAL VOC(The PASCAL Visual Object Classes)作为基准测试数据集。NWPU VHR-10数据集含有10个地理空间对象类的遥感图片。PASCAL VOC数据集则包括20个类。

(2)实现细节。使用COCO数据集上的预训练权重进行初始化。训练策略使用momentum beta = 0.937的随机梯度下降(SGD)方法,权重衰减为 5×10^{-4} ,学习率策略的warmup_epochs为3.0,warmup_

momentum为0.8,warmup_bias_lr为0.1。微调轮数为50epochs。训练过程中的图片大小均设为 640×640 。OOS参数设置为最大进化代数 $N = 10$,种群数 $n = 27$,阶段数 $T = 0.3N$ 。YOLO-GA^[9]方法采用的YOLOv5项目中的原有设置,变异概率为0.8,总的搜索代数与OOS保持一致。

(3)评价指标。#Param为模型参数量,FLOPs为模型浮点运算量,mAP@0.5为IOU阈值为0.5的平均精度,mAP@0.5-0.95为IOU阈值为0.5~0.95的平均精度。

2.2 实验结果与分析

2.2.1 NWPU VHR-10数据集的对比实验

为评估OOS的有效性,采用COCO的评价指标,在相同的实验设置下,对设计的子策略超参数进行10次重复实验。3个基准模型分别为YOLOv5s(r6.1)^[23]、YOLOv5s-Transformer^[23]、YOLOv7,性能指标统计结果如表1所示。

由表1可知,相比于原始模型,使用OOS的方法,在YOLOv5s模型上使mAP@0.5和mAP@0.5-0.95指标分别从93.16%和58.65%提升到93.94%(+0.78%)和60.00%(+1.35%);在YOLOv5s-Transformer模型上,使mAP@0.5和mAP@0.5-0.95指标从92.74%和58.20%提升到93.18%(+0.44%)和60.08%(+1.88%);在YOLOv7模型上,使mAP@0.5和mAP@0.5-0.95指标分别从93.29%和56.48%提升到93.45%(+0.16%)和56.98%(+0.5%)。

观察图1~图3可知,在mAP@0.5指标上,YOLOv7-OOS模型上精度的中位数和鲁棒性均优于YOLO-GA方法。在mAP@0.5-0.95和Fitness指标上,YOLOv5s、YOLOv5s-Transformer模型上精度的中位数均优于YOLO-GA方法,在YOLOv7模型上的中

表1 各模型在NWPU VHR-10上的性能指标统计结果

Table 1 Statistical results of performance metrics of each model on NWPU VHR-10

| 模型 | #Param /M | FLOPs /G | mAP@ 0.5/% | mAP@0.5- 0.95/% |
|----------------------------------|--------------|-------------|---------------|--------------------|
| YOLOv5s | 7.2 | 16.5 | 93.16 | 58.65 |
| YOLOv5s + YOLO-GA | 7.2 | 16.5 | 93.22 | 58.22 |
| YOLOv5s + OOS | 7.2 | 16.5 | 93.94 | 60.00 |
| YOLOv5s-Transformer | 7.2 | 15.9 | 92.74 | 58.20 |
| YOLOv5s-Transformer + YOLO-GA | 7.2 | 15.9 | 93.50 | 59.17 |
| YOLOv5s-Transformer + OOS | 7.2 | 15.9 | 93.18 | 60.08 |
| YOLOv7 | 36.9 | 104.7 | 93.29 | 56.48 |
| YOLOv7 + YOLO-GA | 36.9 | 104.7 | 93.20 | 57.04 |
| YOLOv7 + OOS | 36.9 | 104.7 | 93.45 | 56.98 |




图1 NWPU VHR-10 上不同方法的 mAP@0.5 盒子图
Fig. 1 Box plots of mAP@0.5 for different methods on the NWPU VHR-10 dataset




图2 NWPU VHR-10 上不同方法的 mAP@0.5-0.95 盒子图
Fig. 2 Box plots of mAP@0.5-0.95 for different methods on the NWPU VHR-10 dataset




图3 NWPU VHR-10 上不同方法的适应度盒子图
Fig. 3 Box plots of fitness for different methods on the NWPU VHR-10 dataset

位数则与 YOLO-GA 方法相近、但有着更高的峰值。OOS 方法能提升模型精度。

为进一步验证 OOS 与模型的结合是否具有显著的提升效果,实验以 OOS 方法为基准进行 t 检验,结果如表 2 所示。

表 2 NWPU VHR-10 上的 t 检验结果

Table 2 t -test results on the NWPU VHR-10 dataset

| 模型 | 绝对提升/% | 相对提升/% | t 检验 | 是否显著 |
|-------------------------------|-----------|--------|---------------------------------------|------|
| YOLOv5s | 1.297 00 | 2.09 | $t=5.089,$ $p=6.6 \times 10^{-4}$ | 是 |
| YOLOv5s + YOLO-GA | 1.675 00 | 2.71 | $t=8.812,$ $p=1 \times 10^{-5}$ | 是 |
| YOLOv5s-Transformer | 1.739 00 | 2.82 | $t=12.776,$ $p=4.5 \times 10^{-7}$ | 是 |
| YOLOv5s-Transformer + YOLO-GA | 0.788 00 | 1.26 | $t=7.663,$ $p=3.1 \times 10^{-5}$ | 是 |
| YOLOv7 | 0.466 00 | 0.77 | $t=4.246,$ $p=2.2 \times 10^{-3}$ | 是 |
| YOLOv7 + YOLO-GA | -0.000 29 | -0.05 | $t=-0.476,$ $p=0.645$ | 否 |

注: t, p 分别表示 t 检验中的检验统计量和极端情况出现的概率。

由表 2 可知,在 YOLOv5s 上,OOS 相对于原始模型提升 2.09%,且具有显著性;相对于 YOLO-GA 提升 2.71%,且具有显著性。在 YOLOv5s-Transformer 上,OOS 相对于原始模型提升 2.82%,且具有显著性;相对于 YOLO-GA 方法提升 1.26%,且具有显著性。在 YOLOv7 上,OOS 相对于原始模型提升 0.77%,且具有显著性;同 YOLO-GA 方法相比无显著差异。

综上,OOS 对应的盒子图分布更加密集,异常值较少,模型鲁棒性更强。

2.2.2 PASCAL VOC 数据集的对比实验

为评估 OOS 的有效性,在相同的实验设置下,对设计的子策略超参数进行 10 次重复实验。3 个基准模型分别为 YOLOv5s (r6.1)、YOLOv5s-Transformer、YOLOv7,实验数据如表 3 所示。

由表 3 可知,相比于原始模型,使用 OOS 的方法,在 YOLOv5s 模型上使 mAP@0.5 和 mAP@0.5-0.95 指标分别从 83.97% 和 60.38% 提升到 85.81% (+1.84%) 和 62.27% (+1.89%);在 YOLOv5s-Transformer 模

表 3 PASCAL VOC 上的实验结果

Table 3 Experimental results on the PASCAL VOC dataset

| 模型 | #Param/ | | mAP@0.5/% | mAP@0.5-0.95/% |
|-------------------------------|---------|-------|-----------|----------------|
| | M | G | | |
| YOLOv5s | 7.2 | 16.5 | 83.97 | 60.38 |
| YOLOv5s + YOLO-GA | 7.2 | 16.5 | 85.44 | 62.38 |
| YOLOv5s + OOS | 7.2 | 16.5 | 85.81 | 62.27 |
| YOLOv5s-Transformer | 7.2 | 15.9 | 83.04 | 58.64 |
| YOLOv5s-Transformer + YOLO-GA | 7.2 | 15.9 | 84.51 | 60.08 |
| YOLOv5s-Transformer + OOS | 7.2 | 15.9 | 84.59 | 58.89 |
| YOLOv7 | 36.9 | 104.7 | 87.83 | 68.15 |
| YOLOv7 + YOLO-GA | 36.9 | 104.7 | 89.96 | 70.96 |
| YOLOv7 + OOS | 36.9 | 104.7 | 90.62 | 71.91 |

型上使 mAP@0.5 和 mAP@0.5-0.95 指标分别从 83.04% 和 58.64% 提升到 84.59% (+1.55%) 和 58.89% (+0.25%); 在 YOLOv7 模型上使 mAP@0.5 和 mAP@0.5-0.95 指标分别从 87.83% 和 68.15% 提升到 90.62% (+2.79%) 和 71.91% (+3.76%)。

由图 4~图 6 可知, OOS 方法在 3 个模型上相对于原始模型都有效地提升模型精度, 且相比于 YOLO-GA 提升较为明显。其在 mAP@0.5 指标上, YOLOv5s-OOS、YOLOv7-OOS 模型上精度的中位数和鲁棒性均优于 YOLO-GA 方法。其在 mAP@0.5 指标和 Fitness 指标上, YOLOv7-OOS 模型上的中位数精度和鲁棒性均优于 YOLO-GA 方法。

为进一步观察 OOS 与模型的结合是否具有显著的提升效果, 进行了 *t* 检验分析, 结果如表 4 所示。

由表 4 可知, 在模型 YOLOv5s 上, OOS 相对原始模型提升 3.01%, 且具有显著性; 但相对于 YOLO-GA 表现性能相近, 不具有显著性。在模型 YOLOv5s-Transformer 上, OOS 相对于原模型提升

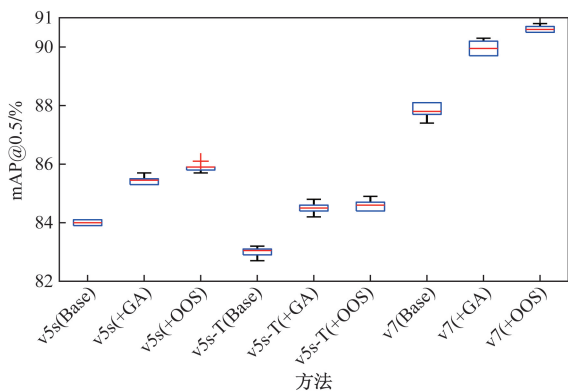


图 4 PASCAL VOC 上不同方法的 mAP@0.5 盒子图
Fig. 4 Box plots of mAP@0.5 for different methods on the PASCAL VOC dataset




图 5 PASCAL VOC 上不同方法的 mAP@0.5-0.95 盒子图
Fig. 5 Box plots of mAP@0.5-0.95 for different methods on the PASCAL VOC dataset




图 6 PASCAL VOC 上不同方法的适应度盒子图
Fig. 6 Box plots of fitness on the PASCAL VOC dataset with different methods

表 4 在 PASCAL VOC 上的 *t* 检验结果

Table 4 The *t*-test results on the PASCAL VOC dataset

| 模型 | 绝对提升/% | 相对提升/% | <i>t</i> 检验 | 是否显著 |
|-------------------------------|--------|--------|--|------|
| YOLOv5s | 1.89 | 3.01 | $t = 25.239,$ $p < 1.0 \times 10^{-9}$ | 是 |
| YOLOv5s + YOLO-GA | -0.06 | -0.09 | $t = 1.031,$ $p = 0.329$ | 否 |
| YOLOv5s-Transformer | 0.38 | 0.62 | $t = 7.183,$ $p < 1.0 \times 10^{-4}$ | 是 |
| YOLOv5s-Transformer + YOLO-GA | -1.06 | -1.70 | $t = 13.857,$ $p < 1.0 \times 10^{-6}$ | 是 |
| YOLOv7 | 3.66 | 5.22 | $t = 73.619,$ $p < 1.0 \times 10^{-13}$ | 是 |
| YOLOv7 + YOLO-GA | 0.92 | 1.26 | $t = 57.751,$ $p < 1.0 \times 10^{-12}$ | 是 |

注: *t*, *p* 分别表示 *t* 检验中的检验统计量和极端情况出现的概率。

0.62%, 且具有显著性; 但相对于 YOLO-GA 略有所下降。在模型 YOLOv7 上, OOS 相对于原始模型提升 5.22%, 且具有显著性; 相对于 YOLO-GA 提升 1.26%, 且具有显著性。

综上可知, YOLOv5s、YOLOv7、YOLOv5s-Transformer 模型在 PASCAL VOC 数据集上的实验表明, 相对于原模型, 在使用 OOS 设计的正则化策略后皆有显著的性能提升。

3 结论

提出基于正交优化策略的 YOLO 模型超参数优化方法实现超参数智能优化。该方法将正交设计理论和多因素多水平的试验设计方法引入超参数优化, 基于统计学的正交试验原理提出种群的正交搜索方; 利用种群的正交性特点设计超参数贡献度分析策略, 以提高算法的优化效率; 设计两阶段更新策略, 第一阶段采用较大步长进行均匀正交搜索, 第二阶段采用较小步长进行邻域正交搜索, 以

避免方法陷入局部最优和早熟收敛。在 Pascal VOC 和 NWPU VHR-10 两个目标检测数据集上的测试结果表明,所提出的基于正交优化策略的 YOLO 模型超参数优化方法能显著提高 YOLOv7 等目标检测模型的识别精度和鲁棒性。下一步将在其它目标检测模型以及分类、分割等任务上进一步深入研究。

参 考 文 献

- [1] Zhang Y, Wang C, Wang X, et al. FairMOT: on the fairness of detection and re-identification in multiple object tracking[J]. *International Journal of Computer Vision*, 2021, 129(11): 3069-3087.
- [2] 蒲玲玲, 杨柳. 改进 YOLOv5 的多车辆目标实时检测及跟踪算法[J]. *科学技术与工程*, 2023, 23(28): 12159-12167.
Pu Lingling, Yangliu. Improved real-time detection and tracking algorithm for multiple vehicle targets in YOLOv5[J]. *Science Technology and Engineering*, 2023, 23(28): 12159-12167.
- [3] Feng D, Haase-Schutz C, Rosenbaum L, et al. Deep multi-modal object detection and semantic segmentation for autonomous driving: datasets, methods, and challenges[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 22(3): 1341-1360.
- [4] Zheng J J, Zou Y Y, Xu J, et al. A method for object recognition and robot grasping detection in multi-object scenes[C]//15th International Conference on Intelligent Robotics and Applications. Harbin: Springer International Publishing, 2022: 189-196.
- [5] Han R, Liu X H, Chen T, et al. YOLO-SG: saliency-guided detection of small objects in medical images[C]//2022 IEEE International Conference on Image Processing. Bordeaux: IEEE, 2022: 4218-4222.
- [6] 陈国栋, 林愉翔, 赵志峰, 等. 基于改进 YOLOv3 的施工升降机螺栓状态检测研究[J]. *贵州大学学报(自然科学版)*, 2022, 39(6): 81-86.
Chen Guodong, Lin Yuxiang, Zhao Zhifeng, et al. Research on bolt condition detection of construction hoist based on improved YOLOv3[J]. *Journal of Guizhou University (Natural Sciences)*, 2022, 39(6): 81-86.
- [7] 陈国栋, 王翠瑜, 张神德, 等. 基于改进 YOLOv3 的塔式起重机裂缝检测研究[J]. *贵州大学学报(自然科学版)*, 2021, 38(3): 76-82.
Chen Guodong, Wang Cuiyu, Zhang Shende, et al. Research on crack detection of tower crane based on improved YOLOv3[J]. *Journal of Guizhou University (Natural Science)*, 2021, 38(3): 76-82.
- [8] Li H Y, Yang G C. Dietary nutritional information autonomous perception method based on machine vision in smart homes[J]. *Entropy*, 2022, 24(7): 868-874.
- [9] Chien-Yao W, Bochkovskiy A, Hong-Yuan M L. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2023: 7464-7475.
- [10] Kaur S, Aggarwal H, Rani R. Hyper-parameter optimization of deep learning model for prediction of Parkinson's disease[J]. *Machine Vision and Applications*, 2020, 31(5): 31-46.
- [11] López D, Alaíz C M, Dorronsoro J R. Modified grid searches for hyper-parameter optimization[M]. Cham: Springer International Publishing, 2020: 221-232.
- [12] Abbasimehr H, Shabani M, Yousefi M. An optimized model using LSTM network for demand forecasting[J]. *Computers & Industrial Engineering*, 2020, 143: 1-13.
- [13] Motta D, Santos A Á B, Machado B A S, et al. Optimization of convolutional neural network hyperparameters for automatic classification of adult mosquitoes [J]. *PLoS One*, 2020, 15(7): e234959.
- [14] Gil-Gamboa A, Paneque P, Trull O, et al. Medium-term water consumption forecasting based on deep neural networks[J]. *Expert Systems with Applications*, 2024, 4: 247-263.
- [15] Felicetti M J, Wang D. Deep stochastic configuration networks with optimised model and hyper-parameters[J]. *Information Sciences*, 2022, 600: 431-441.
- [16] Liashchynskiy P. Grid search, random search, genetic algorithm: a big comparison for NAS [J]. *arXiv Preprint*, 2019: DOI: 10.48550/arXiv.1912.06059.
- [17] Fan D, Maliki N, Yu S W, et al. Enhancing urban blue-green landscape quality assessment through hybrid genetic algorithm-back propagation(GA-BP) neural network approach: a case study in Fucheng, China [J]. *Environmental Monitoring and Assessment*, 2024, 196(5): 1-20.
- [18] Nikbakht S, Anitescu C, Rabczuk T. Optimizing the neural network hyperparameters utilizing genetic algorithm[J]. *Journal of Zhejiang University: Science A*, 2021, 22(6): 407-426.
- [19] Li C, Deng L, Qiao L, et al. An efficient differential evolution algorithm based on orthogonal learning and elites local search mechanisms for numerical optimization[J]. *Knowledge-Based Systems*, 2022, 235: 107636.
- [20] Chien-Yao W, Bochkovskiy A, Liao H M. Scaled-YOLOv4: scaling cross stage partial network[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2021: 13024-13033.
- [21] Zhang H, Cisse M, Dauphin Y N, et al. Mixup: beyond empirical risk minimization [C]//2018 International Conference on Learning Representations (ICLR), Washington, DC: ICLR, 2018: 1-13.
- [22] Golnaz G Y C A S. Simple copy-paste is a strong data augmentation method for instance segmentation[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2021: 2917-2927.
- [23] Jocher G. YOLOv5 release v6.1 [EB/OL]. (2022-02-22) [2023-10-12]. <https://github.com/ultralytics/yolov5/releases/tag/v6.1>.